DOI: 10.48011/asba.v2i1.1286

Predição de pragas e doenças no cafeeiro utilizando Redes Neurais Artificiais

Thiago Andrade [*] **Rogério Antônio Silva** [**]
Christiano de Sousa Machado de Matos [***]
Margarete Marin Lordelo Volpato [****]
Alessandro Botelho Pereira [†] **Danton Diego Ferreira** [‡]

[*] *Programa de Pós-Graduação em Engenharia de Sistemas e Automação, Universidade Federal de Lavras, MG, (e-mail: thio3000@gmail.com)*
[**] *Empresa de Pesquisa Agropecuária de Minas Gerais, MG (e-mail: rogeriosilva@epamig.br)*
[***] *Empresa de Pesquisa Agropecuária de Minas Gerais, MG (e-mail: cmatosepamig@gmail.com)*
[****] *Empresa de Pesquisa Agropecuária de Minas Gerais, MG (e-mail: margovolpato@gmail.com)*
[†] *Empresa de Pesquisa Agropecuária de Minas Gerais, MG (e-mail: lessandro1989@hotmail.com)*
[‡] *Departamento de Automática, Universidade Federal de Lavras, MG (e-mail: danton@ufla.br)*

Abstract: The pests and diseases in the coffee tree, caused by the miner bug, coffee borer, rust and cercosporiosis, reach up to 50 % of a coffee plantation, which can cause great damage to coffee growers. Therefore, intelligent systems are of paramount importance to predict such damage to coffee tree. Artificial neural networks, like Multilyer Perceptron, were the intelligent systems used in this work to predict the percentage of pests occurrence and diseases incidence in the coffee tree. Meteorological data were used as input, say: minimum and maximum temperatures, rainfall, relative air humidity, incidence of sunlight and atmospheric pressure. The value of data referring to pests and diseases was given quantitatively and was collected at the EPAMIG Experimental Field in São Sebastião do Paraíso, in the south of Minas Gerais. The statistical metrics RMSE and R^2 were used to verify how the artificial neural network model is predicting the manifestations of pests and diseases adequately.

Resumo: As pragas e doenças no cafeeiro, ocasionadas por bicho-mineiro, broca-do-café, ferrugem e cercosporiose, chegam a atingir até 50% de uma lavoura cafeeira, podendo causar grandes prejuízos aos cafeicultores. Sendo assim, os sistemas inteligentes são de suma importância para predizer esses danos ao cafeeiro. As redes neurais artificiais do tipo perceptron multicamadas, foram os sistemas inteligentes utilizados neste trabalho para prever a porcentagem de ocorrência de pragas e incidência de doenças no cafeeiro. Foram utilizados dados meteorológicos, tais como: temperaturas mínima e máxima, precipitação pluviométrica, umidade relativa do ar, incidência de raios solares e pressão atmosférica como variáveis de entrada do modelo. O valor dos dados referentes às pragas e doenças se deram quantitativamente e foram coletados no Campo Experimental da EPAMIG de São Sebastião do Paraíso, no sul de Minas Gerais. Foram empregadas as métricas estatísticas RMSE e R^2 para verificar o quão o modelo de rede neural artificial proposto está predizendo as manifestações de pragas e doenças adequadamente.

Keywords: Prediction; MLP Neural Networks; Coffe; Diseases and Pests.
Palavras-chaves: Predição; Redes Neurais MLP; Doenças e Pragas em Cafeeiro.

1. INTRODUÇÃO

Pertencente ao grupo das commodity, o café é o produto que possui grande importância econômica para o Brasil, uma vez que, atualmente, o país é o maior produtor de café da espécie *Coffea arábica* do mundo segundo o *United States Department of Agriculture*. Sendo assim, a produção de café é um dos setores que mais colabora na formação do Produto Interno Bruto (PIB) nacional, gerando empregos diretos e indiretos (Thamada et al., 2015).

O cultivo do cafeeiro é uma atividade agrícola que estabelece constantemente desafios aos cafeicultores, devido a grande quantidade de pragas e doenças presentes ao agroecossistema cafeeiro. Portanto, é necessário vencer este desafio para que possamos produzir café em quantidade e com qualidade, sem causar danos ao meio ambiente e prejuízos econômicos ao produtor (Martins et al., 2011).

Distúrbios bióticos, como as pragas e doenças, e abióticos, como as condições climáticas, podem iniciar uma ação prejudicial aos cafeeiros, ocasionando anormalidades que resultam na perda de produção, e também no declínio da planta (Silva et al., 2010; Machado et al., 2010). Tais distúrbios podem ser prevenidos por meio de estudo epidemiológico das interações patógeno, hospedeiro e ambiente, o que é fundamental para o manejo integrado de pragas e doenças no cafeeiro (Reis et al., 2010; Neto et al., 2013).

Existem duas pragas consideradas chaves no agroecossistema cafeeiro do Brasil. A primeira delas é o bicho-mineiro-do-cafeeiro (*Leucoptera coffeella* Guérin-Méneville) (Lepidoptera : Lyonetiidae), considerada a praga de maior importância na cultura do cafeeiro do país (Conceição et al., 2005). A segunda é a broca-do-café (*Hypothenemus hampei* - Coleoptera: Scolytidae) (Fernandes et al., 2014).

Por outro lado, também possuem dois tipos de doenças em cafeeiros no país. Sendo a primeira a ferrugem-do-cafeeiro (*Hemileia vastatrix* Berk. & Br.), considerada a principal doença encontrada nas lavouras (Thamada et al., 2015). Ela é causada por um fungo endofítico que agride a folha do café adulto, especialmente as plantas mais velhas (Marcos et al., 2019). A segunda doença é a cercosporiose ou "mancha-de-olho-pardo", (*Cercospora coffeicola* Berk. & Cooke) (Botelho et al., 2005).

Diante disso, ferramentas de desenvolvimento de modelos de predição ou alerta, podem ser utilizadas visando antecipar possíveis ataques de pragas e incidência de doenças em cafeeiros, sendo que quando uma predição for realizada corretamente pode-se evitar aplicações preventivas de defensivos agrícolas. Nesse sentindo, sistemas inteligentes vêm sendo utilizados para tentar predizer com uma maior probabilidade de acerto a ocorrência de pragas e incidência de doenças em cafezais. Estes sistemas levam em consideração fatores que estão diretamente ligados com essas manifestações (de pragas e doenças), nas quais podem ser uma faixa de temperatura ao longo dos dias ou a ocorrência de grandes períodos chuvosos, precipitação pluviométrica, insolação, pressão atmosférica ou até mesmo a umidade relativa do ar, todos estes, presentes no agroecossistema cafeeiro (Meira et al., 2008).

As Redes Neurais Artificiais (RNA) são capazes de serem utilizadas para predição e classificação de padrões (Silva et al., 2017). O *perceptron* é uma forma simples de uma rede neural artificial da qual sua principal aplicação se dá nos problemas de classificações de padrões. Entretanto, as arquiteturas do tipo MLP, do inglês *Multi Layer Perceptron*, constituem os modelos neurais artificiais mais utilizados e conhecidos. Uma rede MLP é subdividida em camadas que são: camada de entrada, camadas intermediárias e camada de saída (Tavares et al., 2016).

Contudo, as redes MLPs têm sido aplicadas com êxito para resolver uma gama de problemas, por meio do treinamento de forma supervisionada com a utilização do algoritmo de retropropagação do erro *(backpropagation)*, o qual apresenta duas fases distintas. Na primeira fase, ocorre a propagação do sinal funcional *(feedforward)* mantendo-se os pesos fixos para gerar um valor de saída a partir das entradas fornecidas à rede. Por outro lado, na segunda fase, as saídas são comparadas com os valores desejados, gerando um sinal de erro, que se propaga da saída para a entrada, ajustando-se os pesos de forma a minimizar o erro (Silva et al., 2019).

Sendo assim, o presente artigo propõe o uso de redes neurais MLP para predizer a porcentagem de manifestações de bicho-mineiro, broca-do-café, ferrugem e cercosporiose em cafeeiros.

A Seção 2 apresenta a metodologia e os materiais utilizados no presente trabalho. Os resultados e as análises das simulações são apresentadas na Seção 3. As conclusões e considerações relevantes estão na Seção 4 deste trabalho.

2. MATERIAIS E MÉTODOS

Para os treinamentos das redes MLPs, foram utilizados dados meteorológicos extraídos da plataforma (LaRC, 2020). Por outro lado, a EPAMIG (Empresa de Pesquisa Agropecuária de Minas Gerais) forneceu dados das amostras coletadas de bicho-mineiro, broca-do-café, ferrugem e cercosporiose, todos estes, de um campo experimental localizado na cidade de São Sebastião do Paraíso, Minas Gerais, Brasil. Neste caso, foram coletadas folhas e frutos de café, Tabela 1, e verificou-se o percentual de tais manifestações. As coletas foram realizadas uma vez ao mês de janeiro de 2015 a dezembro de 2019. Vale ressaltar que a coluna Exemplares na Tabela 1 refere-se ao número de amostras de folha e/ou fruto usado no levantamento do percentual de infestações/infecções (pragas ou doenças), enquanto que o número de amostras disponíveis para o desenvolvimento do trabalho está relacionado na coluna Dados, para cada caso.

Tabela 1. Informações sobre amostras coletadas, variáveis e quantidade de dados de pragas e doenças

Pragas/Doenças	Exemplares	Variáveis	Dados
Bicho-mineiro	200	5	60
Broca	1000	5	25
Ferrugem	100	6	60
Cercosporiose	100	6	60

Em função do baixo número de amostras disponíveis em cada caso, utilizou-se a técnica SMOTE (*Sythetic Minority Oversampling Technique*) (Chawla et al., 2006), para criar novas amostras baseadas na interpolação de instâncias

de classes minoritárias dos dados originais. Diante disso, foram utilizados, 180 amostras da praga bicho-mineiro e da doença cercosporiose, 120 amostras da doença ferrugem e 100 amostras da praga broca-do-café no total.

A técnica SMOTE gera dados artificiais por meio de interpolação. Para isto, ela utiliza o algoritmo K-Nearest Neighbors (KNN) (Aha et al., 1991) para produzir representantes entre exemplos e seus k vizinhos. Para tanto, um exemplo da classe minoritária é selecionado e o vetor obtido pela diferença entre o elemento em consideração e seu vizinho é multiplicado por um número aleatório no intervalo entre 0 e 1. Este novo vetor é aplicado sobre o elemento em consideração, em que é selecionado um ponto no espaço, o qual fica na reta entre o elemento e seu vizinho. Portanto, um novo ponto que representa a classe minoritária é gerado. Este processo é representado pela equação 1.

$$x_{novo} = x_i + (\hat{x}_i - x_i)\gamma \quad (1)$$

Em que x_i é o exemplo selecionado; $\hat{x}_i$ é o seu vizinho mais próximo; γ é o número aleatório entre 0 e 1.

Os dados meteorológicos, que são referentes ao mês anterior da coleta das amostras de pragas e doenças, são variáveis de entradas e consistem em: temperaturas minímas e máximas (em graus Celsius), precipitação pluviométrica (em milímetros), incidência de raios solares (insolação - em horas), pressão atmosférica (em pascal) e umidade relativa do ar (em valor absoluto - dado em porcentagem). Para cada um destes dados, foram calculadas as médias para o mês, já que os valores são diários. Como variável de saída, a ser estimada, considerou-se o percentual de manifestações de doenças ou pragas, de acordo com o percentual de exemplares coletado e analisado (vide Tabela 1).

Para o treinamento da rede neural MLP proposta, foi utilizado a metodologia de validação cruzada denominada k-fold, em que manteve-se o total de 20 amostras de dados por *fold*.

A rede neural MLP proposta possui duas camadas intermediárias, em que variaram-se experimentalmente a quantidade de neurônios destas camadas e percebeu-se a melhor combinação dos mesmos. Em seguida, fixou-se esta combinação de neurônios nas camadas da rede neural em 8 neurônios na primeira camada e 8 na segunda.

Foram utilizados quatro tipos de funções de treinamento na rede neural MLP, que são elas: *Bayesian Regulation backpropagation* (trainbr) (Mackay, 1992), *Levenberg-Marquardt backpropagation* (trainlm) (Hagan and Menhaj, 1994; Hagan et al., 1996), *Resilient backpropagation* (trainrp) (Riedmiller and Braun, 1993) e *Scaled conjugate gradient backpropagation* (trainscg) (Moller, 1993).

Para validar as redes neurais MLP, foram utilizadas dois tipos de métricas: RMSE (*Root Mean Square Error*) e o coeficiente de determinação (R^2).

3. RESULTADOS E DISCUSSÕES

Esta seção apresenta os resultados obtidos pelo método proposto para cada uma das bases de dados.

3.1 Bicho-Mineiro-do-cafeeiro

Os resultados apresentados na Tabela 2 são referentes aos valores médios de 9 *folds*. Os algoritmos de treinamento trainbr e trainlm apresentaram um melhor desempenho, tanto de RMSE quanto de R^2.

Tabela 2. Média e desvio padrão do RMSE e R^2 para cada função de treinamento da praga bicho-mineiro

Função	RMSE ($\mu \pm \sigma$)	R^2 ($\mu \pm \sigma$)
trainbr	0,0256 $\pm$0,0063	0,9214 $\pm$0,0313
trainscg	0,0566 $\pm$0,0138	0,5808 $\pm$0,2120
trainlm	0,0255 $\pm$0,0075	0,9034 $\pm$0,0657
trainrp	0,0507 $\pm$0,0101	0,6247 $\pm$0,2345

As Figuras 1 e 2 apresentam os valores reais e previstos da taxa de incidência da praga bicho-mineiro para um *fold* (o de melhor desempenho), para os algoritmos de treinamento trainbr e trainlm, respectivamente.

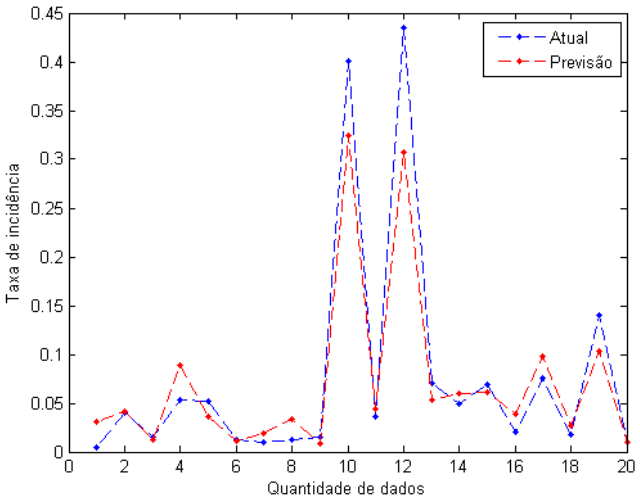

Figura 1. Previsão da taxa de incidência da praga bicho-mineiro para a função de treinamento trainbr.

3.2 Broca-do-café

De acordo com a Tabela 3, as duas funções de treinamento das redes neurais que apresentaram melhores resultados foram as trainbr e trainlm.

Tabela 3. Média e desvio padrão do RMSE e R^2 para cada função de treinamento da praga broca-do-café

Função	RMSE ($\mu \pm \sigma$)	R^2 ($\mu \pm \sigma$)
trainbr	0,0626 $\pm$0,0491	0,9374 $\pm$0,0607
traincsg	0,1523 $\pm$0,0955	0,5967 $\pm$0,2439
trainlm	0,0404 $\pm$0,0184	0,9459 $\pm$0,0396
trainrp	0,1065 $\pm$0,0790	0,7795 $\pm$0,1813

As Figuras 3 e 4 mostram os valores reais e previstos da taxa de incidência da broca-do-café para o *fold* que levou ao melhor resultado, com o algoritmo de treinamento trainbr e trainlm, respectivamente.

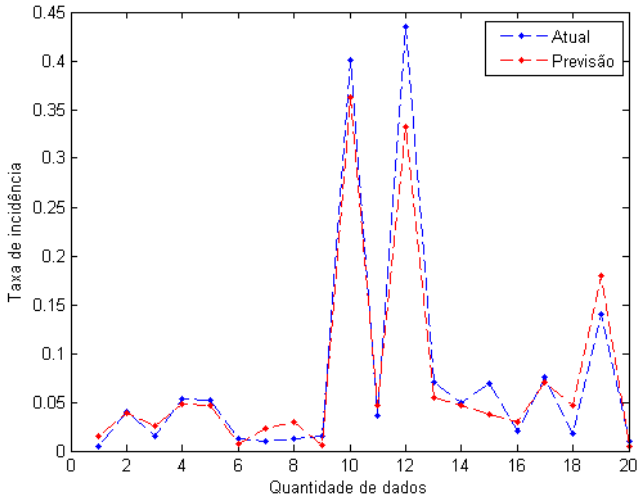

Figura 2. Previsão da taxa de incidência da praga bicho-mineiro para a função de treinamento trainlm.

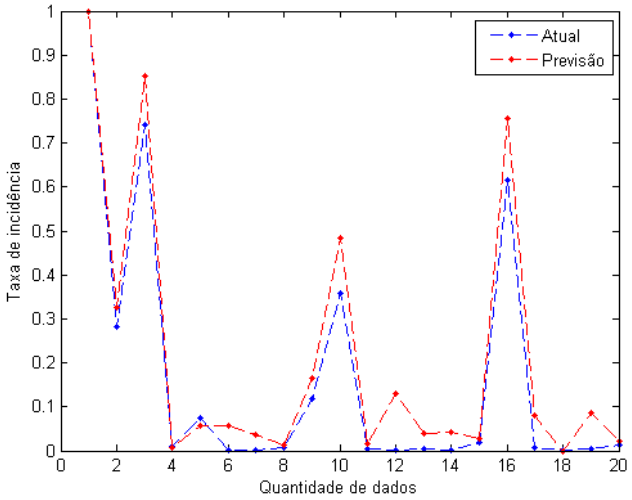

Figura 3. Previsão da taxa de incidência da praga broca-do-café para a função de treinamento trainbr.

3.3 Ferrugem-do-cafeeiro

Os valores médios de RMSE e R^2 são mostrados na Tabela 4 em função dos algoritmos de treinamento da rede neural proposta. Percebe-se que as funções de treinamento trainbr e trainlm, novamente apresentaram menores valores médios de RMSE e maiores valores médios de R^2 do que as outras duas funções de treinamento, como destaque para a função trainbr.

As previsões da doença e os valores reais são mostrados nas Figuras 5 e 6, respectivamente para as funções trainbr e trainlm, para um dos *folds* (o de melhor resultado), evidenciando a eficiência do modelo proposto.

3.4 Cercosporiose

O modelo da rede neural para a doença cercosporiose com as funções de treinamento trainbr e trainlm obteve

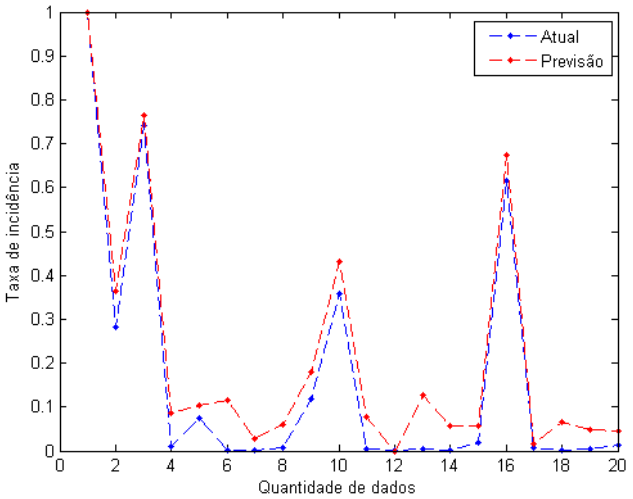

Figura 4. Previsão da taxa de incidência da praga broca-do-café para a função de treinamento trainlm.

Tabela 4. Média e desvio padrão do RMSE e R^2 para cada função de treinamento da doença ferrugem

Função	RMSE ($\mu \pm \sigma$)	R^2 ($\mu \pm \sigma$)
trainbr	0,0821 $\pm$0,0183	0,9398 $\pm$0,0153
traincsg	0,1801 $\pm$0,0102	0,6694 $\pm$0,0635
trainlm	0,1023 $\pm$0,0254	0,8886 $\pm$0,0702
trainrp	0,1532 $\pm$0,0242	0,7538 $\pm$0,0650

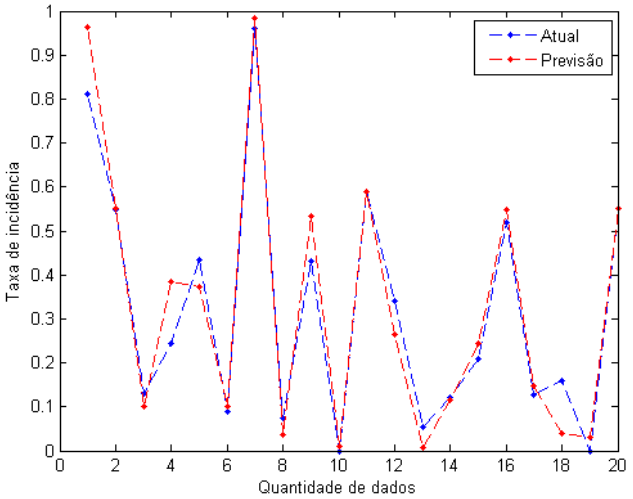

Figura 5. Previsão da taxa de incidência da doença ferrugem para a função de treinamento trainbr.

melhores resultados das métricas estatísticas, conforme mostra a Tabela 5.

As Figuras 7 e 8 são as previsões da doença em comparação com os valores reais quando utilizados as duas funções de treinamento trainbr e trainlm, respectivamente, para um dos *folds*, o de melhor desempenho.

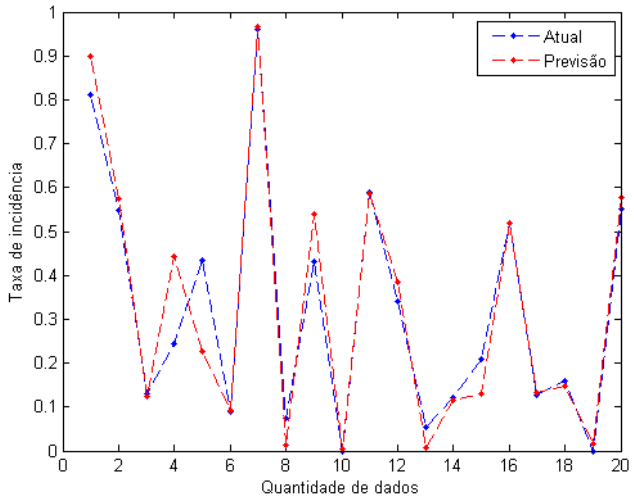

Figura 6. Previsão da taxa de incidência da doença ferrugem para a função de treinamento trainlm.

Tabela 5. Média e desvio padrão do RMSE e R^2 para cada função de treinamento da doença cercosporiose

Função	RMSE ($\mu \pm \sigma$)	R^2 ($\mu \pm \sigma$)
trainbr	0,0212 $\pm$0, 0063	0,9339 $\pm$0, 0322
traincsg	0,0634 $\pm$0, 0127	0,4854 $\pm$0, 1652
trainlm	0,0328 $\pm$0, 0099	0,8592 $\pm$0, 0578
trainrp	0,0606 $\pm$0, 0197	0,5574 $\pm$0, 1839

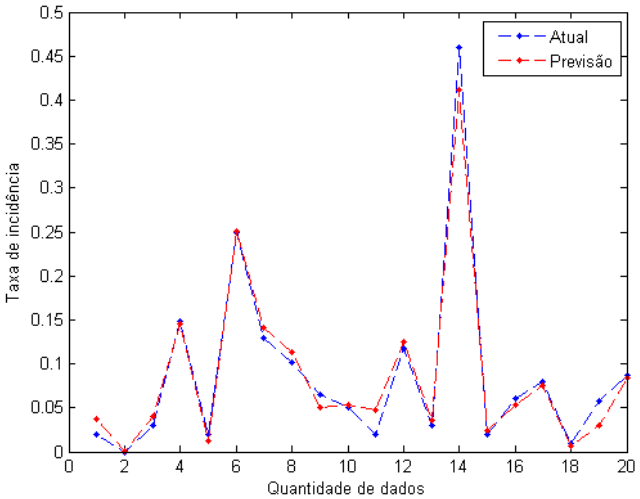

Figura 7. Previsão da taxa de incidência da doença cercosporiose para a função de treinamento trainbr.

4. CONCLUSÃO

As pragas e doenças presentes em cafeeiros causam um grande prejuízo financeiro para os agricultores se não previstas em tempo hábil. Os sistemas inteligentes são algumas das ferramentas existentes que podem auxiliar com maior probabilidade na previsão dessas manifestações danosas para o cafeeiro.

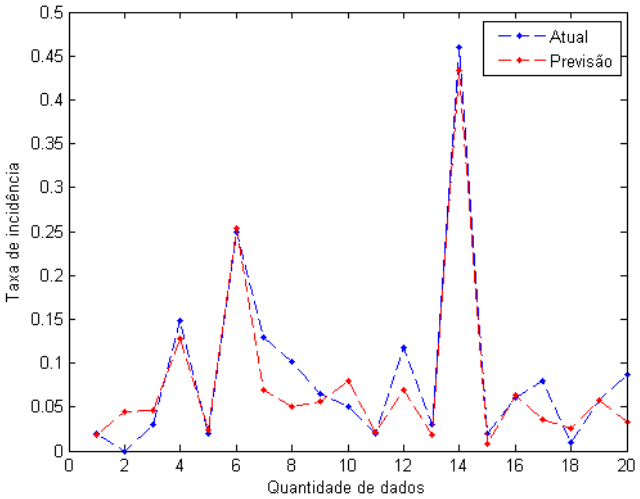

Figura 8. Previsão da taxa de incidência da doença cercosporiose para a função de treinamento trainlm.

A utilização de redes neurais artificiais do tipo MLP mostraram-se uma tecnologia bastante promissora para as previsões abordadas. Os modelos de redes neurais que utilizaram os algoritmos de treinamento trainbr e tranlm, apresentaram os melhores resultados para as métricas RMSE e R^2 para todas as pragas e doenças abordadas neste trabalho.

A pesquisa utilizou uma técnica que gera dados artificiais (SMOTE) para aumentar a base de dados originais para o treinamento e o teste da rede neural. Outras abordagens serão investigadas em trabalhos futuros.

O presente trabalho pode avançar no sentido de realizar estudos comparativos ou até mesmo desenvolver outros modelos de sistemas inteligentes, por exemplo, redes neuro-fuzzy ANFIS.

Um outro avanço que pode ser explorado nessa pesquisa, seria aplicar a rede neural MLP para a predição de pragas e doenças utilizando a técnica dois passos e/ou três passos a frente e analisar o comportamento dessa rede neural por meio das mesmas métricas estatísticas propostas neste trabalho. No contexto deste trabalho, dois passos e três passos a frente significariam dois meses e três meses a frente, respectivamente.

REFERÊNCIAS

Aha, W., Kibler, D., and Albert, M.K. (1991). Instance-Based Learning Algorithms. *Machine Learning*, 6, 37–66. doi:10.1023/A:1022689900470.

Botelho, D.M.S., Pozza, E.A., Pozza, A.A.A., de Carvalho, J.G., Botelho, C.E., and de Souza, P.E. (2005). Intensidade da cercosporiose em mudas de cafeeiro em função de fontes e doses de silício. *Fitopatologia Brasileira*, 30(6), 582–588. doi:10.1590/s0100-41582005000600003.

Chawla, N.V., Bowyer, K.W., Hall, L.O., and Kegelmeyer, W.P. (2006). SMOTE: Synthetic Minority Oversampling Technique. *Journal of Artificial Intelligence Research*, 2009(Sept. 28), 321–357. doi:10.1613/jair.953.

Conceição, C.H.C., Guerreiro-Filho, O., and Gonçalves, W. (2005). Flutuação populacional do bicho-

mineiro em cultivares de café arábica resistentes á ferrugem. *Bragantia*, 64(4), 625–631. doi:10.1590/S0006-87052005000400012.

Fernandes, F.L., Picanço, M.C., da Silva, R.S., da Silva, Í.W., de Sena Fernandes, M.E., and Ribeiro, L.H. (2014). Controle massal da broca-do-café com armadilhas de garrafa Pet vermelha em cafeeiro. *Pesquisa Agropecuaria Brasileira*, 49(8), 587–594. doi:10.1590/S0100-204X2014000800002.

Hagan, M.T., Demuth, H.B., and Beale, M.H. (1996). Neural Network Design. *PWS Publishing*, 12–19.

Hagan, M.T. and Menhaj, M. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, 5, 989–993.

LaRC (2020). Centro de pesquisa langley da nasa (larc). URL `https://power.larc.nasa.gov/`.

Machado, J.L., Silva, R.A., Souza, J.C., Figueiredo, U.J., Carvalho, T.A.F., and Matos, C.S.M. (2010). Mudanças climáticas e as principais pragas do cafeeiro. *Pragas do cafeeiro: bioecologia e manejo integrado - Informe Agropecuário. Belo Horizonte: Epamig*, 35(280), 7–13.

Mackay, D.J.C. (1992). Bayesian interpolation. *Neural Computation*, 4, 415–447.

Marcos, A.P., Rodovalho, N.L.S., and Backes, A.R. (2019). Coffee Leaf Rust Detection Using Convolutional Neural Network. *Proceedings - 15th Workshop of Computer Vision, WVC 2019*, 38–42. doi:10.1109/WVC.2019.8876931.

Martins, L.D., Tomaz, M.A., Souza, A.F., Jesus Júnior, W.C., and Rodrigues, W.N. (2011). Influência da aplicação de ciproconazol + tiametoxam no crescimento de mudas de Coffea canephora Pierre ex A. Froehner. *Revista de Ciências Agrárias*, 34(1), 220–228.

Meira, C.A., Rodrigues, L.H., and Moraes, S.A. (2008). Analysis of coffee leaf rust epidemics with decision tree. *Tropical Plant Pathology*, 33(2), 114–124. doi:10.1590/S1982-56762008000200005.

Moller, M.F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6, 525–533.

Neto, C.D.G., Rodrigues, L.H.A., Thamada, T.T., and Meira, C.A. (2013). Desenvolvimento e Seleção de Modelos de Alerta para a Ferrugem do Cafeeiro em anos de alta Carga Pendente de Frutos. *Journal of Chemical Information and Modeling*, 53(9), 1689–1699. doi:10.1017/CBO9781107415324.004.

Reis, P.R., Souza, J.C., Santa Cecília, L.V.C., Silva, R.A., and Zacarias, M.S. (2010). Manejo integrado das pragas do cafeeiro. *REIS, P. R. CUNHA, R. L. da (Ed.). Café arábica: do plantio à colheita. Lavras: EPAMIG URSM*, 1, 573–688.

Riedmiller, M. and Braun, H. (1993). A direct adaptive method for faster backpropagation learning: The RPROP algorithm. *Proceedings of the IEEE International Conference on Neural Networks*.

Silva, G.N., Nascimento, M., de Castro Sant'Anna, I., Cruz, C.D., Caixeta, E.T., Carneiro, P.C.S., Rosado, R.D.S., Pestana, K.N., de Almeida, D.P., and da Silva Oliveira, M. (2017). Artificial neural networks compared with bayesian generalized linear regression for leaf rust resistance prediction in arabica coffee. *Pesquisa Agropecuaria Brasileira*, 52(3), 186–193. doi:10.1590/s0100-204x2017000300009.

Silva, R.A., Souza, J.C., Reis, P.R., and Santa Cecília, L.V.C. (2010). Sintomas de injúrias causadas pelo ataque de pragas em cafeeiros. *GUIMARÃES, R. J.;MENDES, A. N. G.; BALIZA, D. P. (Ed.). Semiologia do cafeeiro: B. sintomas de desordens nutricionais,fitossanitárias C. e fisiológicas. Lavras: UFLA*, 109–142.

Silva, R.M., Leal, M.R.R., and Lima, F.M. (2019). Predição do Câncer de Mama com Aplicação de Modelos de Inteligencia Computacional. *TEMA - Tendências em Matemática Aplicada e Computacional - Sociedade Brasileira de Matemática Aplicada e Computacional*, 2(229-240). doi:10.5540/tema.2019.020.02.0229.

Tavares, M.H.F., Fleck, L., Eyng, E., Helmann, A.C., and Andrade, M.A.d.M. (2016). Redes Neurais Artificiais: Princípios Básicos. *Revista Eletrônica Científica Inovação e Tecnologia*, 1(13), 47–57.

Thamada, T.T., Rodrigues, L.H.A., and Meira, C.A.A. (2015). Predição da Taxa de Progresso da Ferrugem do Cafeeiro por Meio de Ensembles. *IX Simpósio de Pesquisa Dos Cafés do Brasil 24 a 26 de junho de 2015, Curitiba - PR*, 0–4.